

İşbirlikçi filtreleme için yeni tahminleme yöntemleri New prediction methods for collaborative filtering

Hasan BULUT^{1*}, Musa MİLLİ¹

¹Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Ege Üniversitesi, İzmir, Türkiye.
hasan.bulut@ege.edu.tr, musa.milli@ege.edu.tr

Geliş Tarihi/Received: 18.09.2014, Kabul Tarihi/Accepted: 11.10.2014
* Yazışılan yazar/Corresponding author

doi: 10.5505/pajes.2014.44227
Araştırma Makalesi/Research Article

Öz

Firmalar, özellikle e-ticaret firmaları, öneri sistemleri kullanarak müşteri memnuniyetini, dolayısı ile karlılıklarını artırmayı hedeflemektedirler. Günümüzde Öneri Sistemleri yaygın olarak kullanılmakta ve bunları kullanan firmalara stratejik avantajlar sağlamaktadır. Bu sistemler farklı aşamalardan oluşurlar. İlk aşamada kullanıcı-ürün değerlendirme matrisi kullanılarak aktif kullanıcı ile diğer kullanıcılar arasındaki benzerlikler bulunur. Daha sonra bu benzerliklerden yola çıkılarak aktif kullanıcının yakın komşuları belirlenir. Tahmin hesaplama aşamasında, ilk adımda bulunan benzerlikler kullanılarak aktif kullanıcının yakın komşularının ağırlık vektörü oluşturulur. Komşular tahmin hesaplamasına bu ağırlıklar oranında etki ederler. Bu çalışmamızda işbirlikçi filtreleme algoritmalarının son basamağı olan tahmin hesaplama adımı için yeni yöntemler geliştirilmiştir. Bu yöntemlerin başarımları literatürde kullanılan değerlendirme metrikleri ile ölçülüp bu alanda yapılan çalışmalar ile karşılaştırılmıştır.

Anahtar kelimeler: Öneri sistemleri, İşbirlikçi filtreleme, Tahminleme metodları

Abstract

Companies, in particular e-commerce companies, aims to increase customer satisfaction, hence in turn increase their profits, using recommender systems. Recommender Systems are widely used nowadays and they provide strategic advantages to the companies that use them. These systems consist of different stages. In the first stage, the similarities between the active user and other users are computed using the user-product ratings matrix. Then, the neighbors of the active user are found from these similarities. In prediction calculation stage, the similarities computed at the first stage are used to generate the weight vector of the closer neighbors. Neighbors affect the prediction value by the corresponding value of the weight vector. In this study, we developed two new methods for the prediction calculation stage which is the last stage of collaborative filtering. The performance of these methods are measured with evaluation metrics used in the literature and compared with other studies in this field.

Keywords: Recommender system, Collaborative filtering, Prediction methods

1 Giriş

İnternet'in yaygınlaşması, veri depolama birimlerinin kapasitelerinin artması ve ucuzlaması her geçen gün elektronik ortamda tutulan verilerin artmasına yol açmıştır. Bu verilerin nasıl yorumlanacağı ve bilgiye nasıl ulaşılacağı önemli bir sorun olmaktadır. Bu aşamada öneri sistemleri kullanıcılardan toplanan verileri işleyip anlamlı bilgiler elde etmemizi sağlayan ve bu bilgilerin yorumlanacak düzeye gelmesini sağlayan araçlar olmuşlardır. Dolayısı ile öneri sistemleri aşırı veri ile başa çıkmak için geliştirilen bilgisayar tabanlı zeki tekniklerdir [1].

Günümüzde özellikle e-ticaret sitelerinin ürün yelpazesi oldukça geniştir. Bir kullanıcının bu ürünlerin hepsini incelemesi ve denemesi mümkün değildir. Öneri sistemleri kullanıcıların içerik öğeleri (film, müzik kitap, vb.) hakkındaki geçmişteki ilgi bilgilerini kullanarak daha önce hiç karşılaşmadıkları bir içerik öğesine olan ilgisini hesaplamaya çalışırlar. Yani öneri sistemleri kullanıcıların ilgi duyabileceği ürünleri kullanıcıya önermeyi amaç edinirler [2].

Öneri sistemleri girdi olarak aldıkları bilgiye göre değişik sınıflara ayrılmaktadır. Bu sistemlerden en başarılı olanları ve en tanınmış olanları içerik tabanlı filtreleme ve işbirlikçi filtrelemedir [3],[4]. İçerik tabanlı filtreleme teknikleri, dokümanı içeriğine göre seçip belirli bir metin ararken, işbirlikçi filtreleme teknikleri kullanıcı ilgilerinin benzerliklerini kullanarak aktif kullanıcıya en uygun ürünü önermeye çalışır.

2 Literatür özeti

Öneri sistemleri özellikle e-ticaret hizmeti veren sitelerde gittikçe yaygınlaşmaktadır. MovieReco [5], Ringo [6], VideoRecommender [7] ve MovieLens [8] gibi film içerikli siteler, kullanıcılarına geçmişteki tercihleri üzerinden en uygun filmleri önerirken; Pandora [9] ve last.fm [10] gibi müzik içerikli siteler kullanıcılarına milyonlarca müzik içerisinden en uygun müzikleri önerir. Ayrıca öneri sistemleri Amazon [11], Netflix [12], ve eBay [13] gibi e-ticaret uygulamalarında da kullanılmaktadır. Bu e-ticaret siteleri kullanıcılarına milyonlarca ürün içerisinden ilgilerini çekebilecek ve alabilecekleri ürünleri önerirken şirket karlarını da artırırlar.

1987 yılında yapılan bir çalışmada üç çeşit bilgi filtreleme tekniğinden bahsedilir: Bilişsel, Sosyal ve Ekonomik tabanlı filtreleme [14]. Bilişsel filtreleme teknikleri, dokümanı içeriğine göre seçer ve belirli bir metin arar. Bir diğer içerik tabanlı filtreleme tekniğinde ise kullanıcılar ilgilendikleri dokümanlar içerisindeki her bir terimin frekanslarından oluşan bir ağırlık vektörüne sahiptirler. Bu ağırlık vektörü kullanıcının profilini oluşturur [15]-[17].

İçerik tabanlı filtrelemede kullanıcının daha önce değerlendirdiği ürünlerin profillerine bakılarak kullanıcının göremediği bir ürüne olan ilgisi tespit edilmeye çalışılırken, işbirlikçi filtrelemede ise kullanıcı değerlendirmelerinin benzerliklerinden faydalanır. Ekonomik filtreleme ise ürünün fayda maliyet analizine göre değerlendirir.

İşbirlikçi Filtreleme literatürde ilk defa 1992 yılında Goldberg [18] tarafından Tapestry olarak adlandırılan öneri sisteminin

ortaya atıldığı bir çalışmada geçmektedir [19]. Ayrıca öneri sistemlerinde içerik tabanlı filtreleme bilgi işlemenin başlangıcı olarak kabul edilir.

İşbirlikçi filtreleme, benzer kullanıcılar benzer ilgi ve beğenilere sahiptirler yaklaşımı ile çalışır ve aktif kullanıcı ile benzer olan kullanıcıların söz konusu ürüne verdikleri değerlendirmeleri kullanarak aktif kullanıcının söz konusu ürüne verdiği değer hesaplanmaya çalışılır. Biz bu çalışmamızda, aktif kullanıcının söz konusu ürüne verdiği değerlendirmeyi bulmak için sadece aktif kullanıcı ile benzer olan kullanıcıların değil, aktif kullanıcı ile benzer olmayan kullanıcıların da değerlendirmelerini göz önüne alarak tahminleme yapan yöntemler geliştirdik.

1998 yılında Breese ve diğ. [2] tarafından yapılan çalışmada öneri sistemleri, model tabanlı ve hafıza tabanlı olmak üzere ikiye ayrılmıştır. Bu çalışmada Bayesian ağlarının ve korelasyon metodlarının iyi sonuçlar verdiği saptanmıştır.

1999 yılında Herlocker [20] öneri sistemlerinin değişik basamaklarındaki farklı algoritmaları karşılaştırmış ve şu sonuçları elde etmiştir. Önem ağırlıklandırma $n/50$ ağırlıklandırmasının, komşuluk seçiminde en yakın k komşu algoritmasının, tahmin hesaplama aşamasında ise ortalama farklardan sapma yönteminin diğer yöntemlere ve algoritmalara göre daha iyi sonuçlar verdiği tezini ortaya atmış ve yapılan deneysel çalışmalar ile bu görüşünü ispatlamıştır.

2000 yılında Sarwar ve diğ. [21] Tekil Değer Ayrıştırma (Singular Value Decomposition-SVD) metodu ile kullanıcı ürün değerlendirme matrisinde boyut indirgeme yöntemini ortaya atarak bu alana farklı bir bakış açısı getirmişlerdir. Bu çalışmada SVD, müşteri ve ürünler arasındaki gizli kalmış ilişkileri tespit etmek ve kompleks olan orijinal kullanıcı ürün değerlendirme matrisini küçülterek ölçeklenebilir sistemler tasarlamak amacı ile kullanılmıştır.

2010 yılında Zeng ve diğ. [22] aktif kullanıcıya benzemeyen kullanıcıların da tahminlemeye katkısının olup olmadığını araştırmışlar ve bu kullanıcılar ile aktif kullanıcı arasında bir benzerlik katsayısı hesaplayıp bu katsayıyı da hesaplamaya dahil etmişlerdir. Aktif kullanıcı ile benzemeyen kullanıcıların hesaplama doğruluğuna pozitif yönde etki ettiğini gözlemlemişlerdir. Biz ise bu yayında benzerlik bulma adımında standart Pearson korelasyon katsayısını kullandık. 0 ile 1 aralığında benzerliklere sahip kullanıcılar aktif kullanıcı ile benzeyen, 0 ile -1 aralığında benzerliklere sahip kullanıcılar ise aktif kullanıcı ile benzemeyen kullanıcılarımızı oluşturdu. Daha sonra benzer ve benzer olmayan kullanıcılar ile aktif kullanıcının söz konusu ürüne olan ilgisini hesaplamak için iki farklı tahminleme yöntemi geliştirdik.

3 İşbirlikçi filtreleme yönteminin yapısı

İşbirlikçi filtreleme algoritması öneri sistemlerinin en başarılı yöntemlerindenidir. İşbirlikçi filtreleme algoritmaları benzerlik hesaplaması, komşuluk seçimi ve tahmin hesaplama olmak üzere 3 ayrı hesaplama basamağından oluşmaktadır.

3.1 Benzerlik hesaplaması

İşbirlikçi filtreleme algoritmalarının ilk aşaması kullanıcıların aktif kullanıcı ile benzerliklerini ifade eden ağırlıkları bulmaktır [20]. Bu aşamada aktif kullanıcı ile söz konusu ürünü değerlendirmiş diğer kullanıcılar arasında birlikte değerlendirdikleri ürünler üzerinden bir benzerlik hesaplaması yapılır. Benzerlik bulmada kosinüs benzerliği, Pearson korelasyon katsayısı, ayarlanabilir kosinüs benzerliği

vb. olmak üzere bir çok teknik kullanılmaktadır. Bunlar arasından en başarılı olanı Pearson korelasyon katsayısıdır. Burada bulunan benzerlikler işbirlikçi filtrelemenin daha sonraki aşamalarında farklı amaçlar için kullanılacaktır.

3.1.1 Kosinüs benzerliği

Bu benzerlikte her bir kullanıcı daha önceki değerlendirmelerinin bir vektörü olarak düşünülür. Bu durumda iki vektör arasındaki açının kosinüs değeri, iki vektör arasındaki benzerliği ifade eder. Kosinüs benzerliği Denklem (1) ile hesaplanır.

$$\text{sim}(a, u) = \frac{\sum_{i \in I} R_{a,i} \cdot R_{u,i}}{\sqrt{\sum_{i \in I} R_{a,i}^2} \cdot \sqrt{\sum_{i \in I} R_{u,i}^2}} \quad (1)$$

Denklem (1)'de $\text{sim}(a, u)$ aktif kullanıcı ile u kullanıcısı arasındaki benzerlik değerini; I kümesi aktif kullanıcı ile u kullanıcısının geçmişte ikisinin de değerlendirdikleri ürünlerin kümesini; $R_{a,i}$ aktif kullanıcının i ürününe verdiği değeri; $R_{u,i}$ u kullanıcısının i ürününe verdiği değeri ifade etmektedir.

Kosinüs benzerliğinde iki kullanıcı arasındaki benzerlik 0 ile 1 arasında değerler alır. Sonuç 1'e ne kadar yakın ise kullanıcılar o kadar benzerdir diyebiliriz. Kosinüs benzerliğinde iki kullanıcı arasındaki benzerlik 1 ise, bu kullanıcıların tıpa tıp aynı değerlendirmeleri yaptığını göstermez; iki kullanıcının değerlendirmeleri arasında sabit bir katsayı olduğunu gösterir [23].

3.1.2 Pearson korelasyon katsayısı

Kullanıcılar değerlendirme skalasını farklı algılayabilirler. Bazı kullanıcılar çoğunlukla skalanın üst değerlerini kullanmayı tercih ederlerken bazı kullanıcılar alt değerlerini tercih ederler, diğerleri ise nispeten daha homojen bir kullanım gerçekleştirebilirler. Kosinüs benzerliği kullanıcıların değerlendirme skalasını farklı algılamalarını göz ardı eder. Pearson korelasyon katsayısı ise kullanıcı ortalamalarını da hesaba katarak bu olumsuzluğu azaltır. Yani Pearson korelasyon katsayısı yönteminde kullanıcı değerlendirme vektörü kullanıcı tercih vektörüne dönüştürülür ve tercihler üzerinden hesaplama yapılır. Pearson Korelasyon Katsayısı Denklem (2) ile hesaplanır.

$$\text{sim}(a, u) = \frac{\sum_{i \in I} (R_{a,i} - \bar{R}_a) \cdot (R_{u,i} - \bar{R}_u)}{\sqrt{\sum_{i \in I} (R_{a,i} - \bar{R}_a)^2} \cdot \sqrt{\sum_{i \in I} (R_{u,i} - \bar{R}_u)^2}} \quad (2)$$

Denklem (2)'de $\text{sim}(a, u)$ aktif kullanıcı ile u kullanıcısı arasındaki benzerlik değerini; I kümesi aktif kullanıcı ile u kullanıcısının geçmişte ikisinin de değerlendirdikleri ürünlerin kümesini; $R_{a,i}$ aktif kullanıcının i ürününe verdiği değeri; $R_{u,i}$ u kullanıcısının i ürününe verdiği değeri; \bar{R}_a , a kullanıcısının ürünlere verdiği değerlerin ortalamasını; \bar{R}_u , u kullanıcısının ürünlere verdiği değerlerin ortalamasını ifade etmektedir.

Pearson korelasyon katsayısı benzerliğinde iki kullanıcı arasındaki benzerlik -1 ile 1 arasında değerler alır. Sonuç 1'e ne kadar yakın ise kullanıcılar o kadar benzerdir diyebiliriz.

3.2 Komşuluk seçimi

İşbirlikçi filtreleme algoritmalarının ikinci aşaması komşuluk seçimidir. Bir önceki aşamada bulunan benzerlik değerleri bu aşamada aktif kullanıcıya en yakın komşuları bulmak için

kullanılır. Bu aşamada eşik değer ve k en yakın komşu algoritmaları en çok kullanılan komşuluk seçim yöntemleridir.

Eşik değer yönteminde aktif kullanıcı ile belirli bir değer üzerinde benzerliğe sahip olan kullanıcılar aktif kullanıcının komşuları olarak seçilip hesaplamaya dahil olurlarken; k en yakın komşu yönteminde ise aktif kullanıcı ile benzerliği en yüksek olan k adet kullanıcı seçilip hesaplamaya dahil edilirler.

k en yakın komşu yönteminde veri setine uygun bir k değerinin seçilme zorunluluğu bu algoritmanın dezavantajıdır. Uygun bir k değeri seçilmemesi hesaplamaların doğruluğuna etki edecektir. Eğer k 'yı düşük seçersek aktif kullanıcı ile benzer olan kullanıcıların bir kısmı hesaplamaya dahil edilmeyeceğinden, k 'yı yüksek seçersek de aktif kullanıcı ile benzer olmayan kullanıcılar da hesaplamaya dahil edileceğinden tahminlemenin doğruluğu negatif yönde etkilenecektir. Aslında benzer bir durum eşik değer algoritmasında da vardır. Eşik değeri düşük seçersek aktif kullanıcı ile benzer olmayan kullanıcılar da hesaplamaya dahil edilecek ve tahminlemenin doğruluğunu düşürecektir. Eşik değeri yüksek seçersek de hesaplama kapsamı düşecektir.

3.3 Tahmin hesaplama

Tahmin hesaplama aşamasında ilk aşamada bulunan benzerlik değerleri ağırlık vektörünü oluşturur. Yani bir kullanıcının aktif kullanıcı ile arasındaki benzerlik, onun hesaplamaya ne kadar etki edeceğinin göstergesidir. Bir kullanıcının aktif kullanıcı ile benzerliği çok fazla ise hesaplamaya da çokça etki eder.

Komşuluk seçimi yapıldıktan sonra bu komşuların söz konusu ürüne verdikleri değerlendirmeler birleştirilerek tahmin hesaplanır [20]. Bu aşamada da en başarılı tahmin hesaplama yöntemi ayarlanabilir ağırlıklandırılmış ortalamadır.

Ayarlanabilir ağırlıklandırılmış ortalama, kullanıcıların değerlendirme skalasını nasıl algıladıkları ve alışkanlıkları da dikkate alınır [24],[25]. Bu sebeple daha gerçekçi tahminler yapılır. Ayarlanabilir ağırlıklandırılmış ortalama Denklem (3) ile gösterilmiştir.

$$R_{a,i} = \bar{R}_a + \frac{\sum_{u \in U} (R_{u,i} - \bar{R}_u) \cdot sim(a, u)}{\sum_{u \in U} sim(a, u)} \quad (3)$$

Denklem (3)'de $R_{a,i}$ a kullanıcısının i ürününe verdiği değer tahminini; \bar{R}_a , a kullanıcısının, \bar{R}_u , u kullanıcısının ortalamasını; $sim(a, u)$ a kullanıcısı ile u kullanıcısı arasındaki benzerlik değeri; U kümesi de a kullanıcısının yakın komşularını ifade etmektedir.

4 Önerilen yöntem

İşbirlikçi filtreleme algoritmalarında bir kullanıcının herhangi bir ürüne olan ilgisini bulmak için yapılması gereken ilk iş bu kullanıcı ile söz konusu ürünü değerlendiren kullanıcılar arasındaki benzerliklerin ve aktif kullanıcıya en çok benzeyen kullanıcıların bulunması işlemidir. Literatürde bu alanda iki kullanıcı arasındaki benzerlik genellikle kosinüs benzerliği ve Pearson korelasyon katsayısı gibi yöntemler ile bulunmaktadır.

İşbirlikçi filtreleme algoritmalarının son basamağında ise aktif kullanıcının söz konusu ürüne ilgisinin olup olmadığının bulunduğu tahmin hesaplama aşaması vardır. Tahmin hesaplama aşamasında elde edilen değer, aktif kullanıcının söz konusu ürüne ilgisinin rakamsal değerini verir.

Bu çalışmamızda öneri sistemlerinin tahmin hesaplama aşaması için iki yöntem önerilmiştir.

4.1 Yöntem 1

Tahmin hesaplama aşamasında aktif kullanıcının komşuları kullanılarak söz konusu ürüne olan ilgisi hesaplanmaya çalışılır. Aktif kullanıcının komşuları genellikle aktif kullanıcı ile pozitif korelasyona sahip kullanıcılardır. Bir bakıma aktif kullanıcı ile sadece pozitif benzerliğe sahip kullanıcılar üzerinden tahmin hesaplanır.

Benzer kullanıcılar benzer ilgi ve beğenilere sahip ise farklı kullanıcılar da farklı ilgi ve beğenilere sahiptir. Eğer aktif kullanıcı ile pozitif benzerliğe sahip kullanıcılar üzerinden tahmin hesaplanıyorsa bunun tam tersi de mümkündür. Yani aktif kullanıcı ile negatif benzerliğe sahip kullanıcılar üzerinden de tahmin hesaplanabilir.

a kullanıcısı u kullanıcısı ile benzer ise ve u kullanıcısı i ürününe x değerlendirmesi yapmış ise a kullanıcısının da i ürününe x 'e yakın bir değerlendirme yapması beklenir. Tam tersi bir şekilde a kullanıcısı u kullanıcısı ile farklı ise ve u kullanıcısı i ürününe x değerlendirmesi yapmış ise a kullanıcısının i ürününe x 'ten uzak bir değerlendirme yapmasını bekleriz.

Bu yöntemde aktif kullanıcının söz konusu ürüne olan ilgisi bulunurken pozitif ve negatif benzerliğe sahip kullanıcılardan yararlanılır. Hem pozitif hem de negatif benzerliğe sahip kullanıcılar kullanılacağından benzerlik yöntemi olarak hem pozitif hem de negatif değerler alabilen Pearson korelasyon ve ayarlanabilir kosinüs benzerlikleri kullanılmıştır.

$$Sim_{poz} = \sum_{u \in U^+} Sim(a, u) \quad (4)$$

Denklem (4)'de U^+ aktif kullanıcı ile pozitif benzerliğe sahip olan kullanıcıların kümesini, n ise bu kümedeki eleman sayısını ifade eder.

$$Sim_{neg} = \sum_{u \in U^-} Sim(a, u) \quad (5)$$

Denklem (5)'de U^- aktif kullanıcı ile negatif benzerliğe sahip olan kullanıcıların kümesini, m ise bu kümedeki eleman sayısını ifade eder.

$$\text{Toplam_Benzerlik} = |Sim_{poz}| + |Sim_{neg}| \quad (6)$$

$$\text{Poz_Oran} = Sim_{poz} / \text{Toplam_Benzerlik} \quad (7)$$

$$\text{Neg_Oran} = Sim_{neg} / \text{Toplam_Benzerlik} \quad (8)$$

Denklem (6), (7) ve (8)'de ise pozitif ve negatif kullanıcıların sonuca ne kadar etki edeceğini belirleyen oranlar normalize edilerek bulunmuştur.

$$\overline{R_{Simpoz}} = \frac{\sum_{u \in U^+} R_{u,i}}{n} \quad (9)$$

$$\overline{R_{Simneg}} = \frac{\sum_{u \in U^-} R_{u,i}}{m} \quad (10)$$

Denklem (9) ve (10)'da $\overline{R_{Simpoz}}$ aktif kullanıcı ile pozitif benzerliğe sahip kullanıcıların, $\overline{R_{Simneg}}$ ise aktif kullanıcı ile negatif benzerliğe sahip kullanıcıların söz konusu ürüne yaptıkları değerlendirmelerin aritmetik ortalamasıdır.

$$T_{poz} = \overline{R_a} + (\overline{R_{Simpoz}} - \overline{R_a}) \cdot Poz_Oran \quad (11)$$

$$T_{neg} = \overline{R_a} + (\overline{R_{Simneg}} - \overline{R_a}) \cdot Neg_Oran \quad (12)$$

Denklem (11) ve (12)'de $\overline{R_a}$ aktif kullanıcının ortalaması, T_{poz} pozitif benzer kullanıcılar kullanılarak bulunan tahmin, T_{neg} ise negatif benzer kullanıcılar kullanılarak bulunan tahmin olsun. Son tahmin değeri, Denklem (13)'te gösterildiği gibi hem pozitif benzer kullanıcılardan hem de negatif benzer kullanıcılardan elde edilen sonuçların ağırlıklandırılmış ortalaması olarak hesaplanır.

$$T = \frac{(T_{poz} \cdot n) + (T_{neg} \cdot m)}{n + m} \quad (13)$$

4.2 Yöntem 2

Kullanıcıların ürünlere vermiş oldukları değerlerin standart sapmaları kullanıcıların değerlendirme alışkanlıkları hakkında bilgi verir. Bazı kullanıcılar değerlendirme skalasını daha dar kullanırken, bazı kullanıcılar da daha geniş kullanabiliyor. Yani, bazı kullanıcılar değerlendirme skalasının bütün değerlerini kullanırken bazıları da sadece yüksek veya sadece düşük olan değerleri kullanabiliyor. Bu yüzden Yöntem 2'de kullanıcıların ürünlere verdikleri değerlerin standart sapması da hesaplamaya dahil edildi.

Denklem (4)-(10)'da belirtilen değerler hesaplandıktan sonra Denklem (14) ve Denklem (15) ile δ_{poz} ve δ_{neg} değerleri hesaplanır.

$$\delta_{poz} = \frac{\sum_{u \in U^+} \delta_u}{n} \quad (14)$$

$$\delta_{neg} = \frac{\sum_{u \in U^-} \delta_u}{m} \quad (15)$$

Burada, δ_{poz} pozitif benzer kullanıcıların, δ_{neg} negatif benzer kullanıcıların standart sapmalarının aritmetik ortalamasını ifade eder. $\overline{R_{Simpoz}}$ ve $\overline{R_{Simneg}}$ değerleri aşağıda belirtilen koşullara göre Denklem (16) ve (17)'ye göre veya Denklem (18) ve (19)'a göre hesaplanır:

Eğer $\overline{R_{Simpoz}} > \overline{R_{Simneg}}$ ise

$$\overline{R_{Simneg}} = \overline{R_{Simneg}} - (\delta_{neg} \cdot 0.5) \quad (16)$$

$$\overline{R_{Simpoz}} = \overline{R_{Simpoz}} + (\delta_{poz} \cdot 0.5) \quad (17)$$

Eğer $\overline{R_{Simpoz}} \leq \overline{R_{Simneg}}$ ise

$$\overline{R_{Simneg}} = \overline{R_{Simneg}} + (\delta_{neg} \cdot 0.5) \quad (18)$$

$$\overline{R_{Simpoz}} = \overline{R_{Simpoz}} - (\delta_{poz} \cdot 0.5) \quad (19)$$

Bulunan muhtemel tahmin değeri, pozitif benzer kullanıcıların söz konusu ürün için verdikleri değerlerin ortalamasına yakın ve negatif benzer kullanıcıların söz konusu ürün için verdikleri değerlerin ortalamasına uzak olması beklenir. Bu sebepten dolayı eğer pozitif benzer kullanıcıların ortalaması negatif benzer kullanıcıların ortalamasından yüksek ise aktif kullanıcının söz konusu ürüne yüksek bir değer verdiği düşünülebilir. Bu durumda pozitif benzer kullanıcıların ortalamasına standart sapma ortalamalarının yarısı kadar eklenir, negatif benzer kullanıcıların ortalaması da standart sapma ortalamasının yarısı kadar azaltılır. Diğer durumda

pozitif benzer kullanıcıların ortalaması negatif benzer kullanıcıların ortalamasından küçük ise tam tersi işlemler yapılır.

Bu işlemlerden sonra yine Denklem (11) ve (12)'de olduğu gibi pozitif benzer kullanıcılardan yararlanarak T_{poz} , ve negatif benzer kullanıcılardan yararlanarak T_{neg} değerleri hesaplanır. Son tahmin değeri, Denklem (20)'de gösterildiği gibi T_{poz} ve T_{neg} değerlerinin aritmetik ortalaması alınarak hesaplanır.

$$T = \frac{T_{poz} + T_{neg}}{2} \quad (20)$$

5 Kullanılan veri seti ve değerlendirme ölçütleri

Bu bölümde yayın kapsamında kullanılan veri seti ve öneri sistemlerinin performans ölçümlerinde kullanılan değerlendirme ölçütleri anlatılmıştır.

5.1 Kullanılan veri seti

Öneri sistemleri alanında birçok araştırmacı GroupLens'in 1996 yılında topladığı ve 100000 değerlendirmeden oluşan MovieLens veri setini kullanmıştır. Bu veri setinde değerlendirmeler 1 ile 5 aralığındadır. 943 kullanıcısı ve 1682 filmi (ürün) bulunan bu veri setinde her kullanıcının en az 20 değerlendirmesi mevcuttur.

Bu değerlendirmelerin 80000 tanesi eğitim, 20000 tanesi de test verisi olarak kullanılmıştır. Dolayısı ile 80000 değerlendirme kullanılarak 20000 değerlendirme tahmin edilmiş ve yapılan tahminlemenin başarımı bu alanda kullanılan değerlendirme metrikleri ile ölçülmüştür.

5.2 Değerlendirme ölçütleri

Öneri sistemlerinin performansı kişiselleştirebilme yeteneği, hızı ve doğruluğu gibi kriterler ile ölçülebilir; ancak bir öneri sisteminin kalitesini belirleyen en önemli performans kriteri doğruluktur.

Öneri sistemlerinin doğrulukları iki farklı metrik grubu ile ölçülür: İstatistiksel doğruluk ölçütleri ve karar destek doğruluk ölçütleri. İstatistiksel doğruluk ölçütleri bulunan tahmin değerlerinin gerçek değerlere matematiksel olarak ne kadar yaklaştığının ölçüsüdür. En çok bilinenleri Mean Square Error (MAE), Root Mean Square Error (RMSE), NMAE'dir.

MAE adından da anlaşılacağı üzere hataların mutlak değerlerinin ortalamasıdır. MAE Denklem (21)'deki gibi hesaplanabilir.

$$MAE = \frac{1}{N} \sum_{i=1}^N |R_{u,i} - R_{u,i}'| \quad (21)$$

Burada, N test verilerinin sayısı, $R_{u,i}$ gerçek rate değeri, $R_{u,i}'$ algoritmanın tahmin ettiği değerdir. Bütün gerçek değerlerden tahmin edilen değerler arasındaki sayısal uzaklıkları toplayıp test verilerinin sayısına böldüğümüzde MAE sonucunu elde ederiz.

Değerlendirme skalalarının hepsi aynı aralıklara sahip değildir. Birisi 1-5 arası değerlendirmelere izin verirken bir diğeri 1-10 arası değerlendirmelere izin verebilir. Bu da çıkan sonucun sayısal değerini etkiler. Bu olumsuzluğun etkisini en aza indirmek için NMAE metriği öneri sistemlerinde sıkça kullanılmaktadır. NMAE, MAE'nin farklı değerlendirme skalalarına göre normalize edilmiş halidir.

RMSE’de ise tahmin değerlerinin gerçek değerlere olan yakınlığını bulmak için Denklem (22) kullanılır.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (R_{u,i} - R_{u,i}')^2} \quad (22)$$

Karar destek doğruluk ölçütleri yapılan tahminlemelerin kullanıcıyı istediği ürünlere ne kadar yaklaştırdığının ve istemediği ürünlerden ne kadar uzaklaştırdığının ölçüsüdür. Burada da en çok kullanılanları Alıcı Çalışma Karakteristiği (Receiver Operating Characteristics - ROC) ve F1 ölçütüdür.

6 Deneysel sonuçlar

Deneysel çalışmalarda önerilen tahmin hesaplama yöntemleri, literatürde geçen tahmin hesaplama yöntemleri ile karşılaştırılmıştır. Önerilen yöntemlerin bazı geleneksel yöntemlerden daha iyi olduğu bazı yöntemler ile de yarışabildiği görülmüştür.

Bu bölümde önerilen tahminleme metodlarının geleneksel algoritmalar üzerindeki etkisi incelenmiş ve literatürdeki yöntemler ile karşılaştırılmıştır. Elde edilen sonuçlar Tablo 1’de görülmektedir.

Tablo1: Önerilen yöntemlerin geleneksel yöntemler ile karşılaştırılması.

Tahminleme Yön.	MAE
Basit Ortalama	0.817
Ağırlık Ortalama	0.800
Yöntem 1	0.783
Yöntem 2	0.779

Tablo 1’deki değerler MAE ile hesaplanmış tahminleme hatalarını göstermektedir. Buradaki değerlerin küçük olması gerçek değerler ile tahmin değerleri arasındaki hataların az olması anlamına gelir. Tablo 1 geliştirilen tahminleme yöntemlerinin ikisinin de geleneksel işbirlikçi filtreleme algoritmalarındaki tahminleme metodlarından daha doğru sonuçlar ürettiği gözlenmiştir.

İşbirlikçi filtreleme algoritmaları girdi olarak ne kadar çok değerlendirme bilgisi alırsa o kadar doğru sonuçlar üretirler. Ancak bu algoritmaların üzerinde çalıştıkları kullanıcı ürün değerlendirme matrisinin seyrek oluşu bu algoritmaların daha doğru sonuçlar üretmesindeki en büyük engellerden biridir. Bu sebeple bu çalışmada daha doğru sonuçlar elde edebilmek için aktif kullanıcıyla benzer olmayan komşuları da girdi verisi olarak düşünülmüş ve tahminlemenin doğru artırılmıştır.

Bir sonraki deneyde geliştirilen tahminleme yöntemleri bu alandaki bazı yayınlarda öne sürülmüş yöntemler ile karşılaştırılmış ve elde edilen sonuçlar Tablo 2’de gösterilmiştir.

Tablo 2: Önerilen yöntemlerin literatürdeki bazı çalışmalar ile karşılaştırılması.

Tahminleme Yön.	MAE
Basit Ortalama [20]	1.162
Ağırlık Ortalama [20]	0.765
Pure CF [26]	0.840
Adjusted Cosine [26]	0.728
Traditional CF [27]	0.820
Proposed CF [27]	0.790
Yöntem 1	0.783
Yöntem 2	0.779

Tablo 2’deki sonuçlara göre önerilen tahminleme metodlarının işbirlikçi filtreleme algoritmalarının doğruluğunu arttırdığı ve literatürdeki benzerlerinin bazılarında daha iyi olduğu anlaşılmıştır.

7 Sonuçlar ve öneriler

Bu çalışmamızda farklı bir tahminleme metodu üzerinde durulmuştur. Önerilen bu metodlar işbirlikçi filtreleme algoritmaları üzerinde denenmiş ve başarıları diğer tahmin hesaplama algoritmaları ve geleneksel yöntemler ile karşılaştırılmıştır. Yapılan karşılaştırmalardan önerilen tahminleme metodlarının geleneksel yöntemlerden daha iyi olduğu ve literatürde önerilen diğer algoritmalar ile de baş edebilecek doğrulukta sonuçlar ürettiği gözlenmiştir.

İşbirlikçi filtreleme algoritmalarında sadece benzer kullanıcılardan değil aynı zamanda aktif kullanıcıya benzemeyen kullanıcılardan da yararlanıp işbirlikçi filtreleme algoritmalarının girdisini arttırdık ve daha doğru sonuçlar elde ettik. Sonraki çalışmalarda ürünlerin içerik verilerinden elde edilen bilgiler kullanılarak sonuçlar geliştirilebilir.

8 Kaynaklar

- [1] Vozalis E, Margaritis KG. “Analysis of recommender systems’ algorithms”. *6th Hellenic-European Conference on Computer Mathematics and its Applications*, Athens, Greece, 25-27 September 2003.
- [2] Breese JS, Heckerman D, Kadie C. “Empirical analysis of predictive algorithms for collaborative filtering”. *14th Conference on Uncertainty in Artificial Intelligence*, San Francisco, CA, USA, 24-26 July 1998.
- [3] Mooney RJ, Roy L. “Content-Based book recommending using learning for text categorization”. *22th Annual International ACM SIGIR’99, Workshop on Recommender Systems: Algorithms and Evaluation*, Berkeley, CA, 15-19 August 1999.
- [4] Salter J, Antonopoulos N. “CinemaScreen recommender agent: combining collaborative and content-based filtering”. *IEEE Intelligent Systems*, 21(1), 35-41, 2006.
- [5] Mehdi GD, Dakua J. “MovieReco: A recommendation system”. *2nd World Enformatika Conference, WEC’05*, Çanakkale, Turkey, 25-27 February 2005.
- [6] Shardanand U, Maes P. “Social information filtering: algorithms for automating ‘word of mouth’”. *ACM CHI’95 Conference on Human Factors in Computing Systems*. Denver, Colorado, USA, 7-11 May 1995.
- [7] Hill W, Stead L, Rosenstein M, Furnas GW. “Recommending and evaluating choices in a virtual community of use”. *ACM CHI’95 Conference on Human Factors in Computing Systems*, Denver, Colorado, USA, 7-11 May 1995.
- [8] MovieLens. “MovieLens”. <https://movielens.org>, (14.04.2014).
- [9] Pandora. “http://www.paandora.com/restricted”. <http://www.pandora.com>, (28.07.2013).
- [10] last.fm. “Last.fm- Listen to free music and watch videos with the largest music catalogue online <http://www.last.fm>, (28.07.2013).
- [11] Amazon. “Amazon.com: Online Shopping for Electronics, Apparel, Computers, Books, DVDs & more”. <http://www.amazon.com>, (28.07.2013).
- [12] Netflix. “Netflix - Watch TV Shows Online, Watch Movies Online”. <http://www.netflix.com>, (28.07.2013).
- [13] Ebay. “Electronics, Cars, Fashion, Collectibles, Coupons and More | eBay”. <http://www.ebay.com>, (28.07.2013).

- [14] Malone TW, Grant KR, Turbak FA, Brobst SA, Cohen MD. "Intelligent information sharing systems". *Communications of the ACM*, 30(5), 390-402, 1987.
- [15] Deerwester S, Dumais ST, Furnas GW, Landauer TK, Harshman R. "Indexing by latent semantic analysis". *Journal of the American Society for Information Science*, 41(6), 391-407, 1990.
- [16] Foltz PW, Dumais ST. "Personalized information delivery: an analysis of information filtering methods". *Communications of the ACM*, 35(12), 51-60, 1992.
- [17] Maltz DA. Distributing Information for Collaborative Filtering on Usenet Net News. MS Thesis, Massachusetts Institute of Technology, Cambridge, MA, USA, 1994.
- [18] Goldberg D, Nichols D, Oki BM, Douglas T. "Using collaborative filtering to weave an information tapestry". *Communications of the ACM*, 35(12), 61-70, 1992.
- [19] Melville P, Sindhvani V. *Recommender Systems*. Editors: Sammut C, Webb G. Encyclopedia of Machine Learning, 829-838. New York, NY, USA, Springer, 2011
- [20] Herlocker JL, Konstan JA, Borchers A, Riedl J. "An algorithmic framework for performing collaborative filtering". *22nd Annual International ACM SIGIR'99, Conference on Research and Development in Information Retrieval*, Berkeley, USA, 15-19 August 1999.
- [21] Sarwar BM, Karypis G, Konstan JA, Riedl JT. "Application of Dimensionality Reduction in Recommender System-A Case Study". *ACM WebKDD 2000 Web Mining for E-Commerce Workshop*, 2000.
- [22] Zeng W, Shang M, Zhang Q. "Can dissimilar users contribute to accuracy and diversity of personalized recommendation?". *International Journal of Modern Physics C*, 21(10), 1217-1227, 2010.
- [23] Tan PN, Steinbach M, Kumar V. *Introduction to Data Mining*, 17th ed. Pearson Addison-Wesley, Boston, MA, USA, 2006.
- [24] Adomavicius G, Tuzhilin A. "Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions". *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734-749, 2005.
- [25] Ding Y, Xue Li, Orłowska ME. "Recency-Based collaborative filtering". *17th Australasian Database Conference - ADC '06*, Tasmania, Australia, 16-19 January 2006.
- [26] Sarwar B, Karypis G, Konstan J, Riedl J. "Item-Based collaborative filtering recommendation algorithms". *10th International Conference on World Wide Web*, 285-295, 2001.
- [27] Gong S. "A collaborative filtering recommendation algorithm based on user clustering and item clustering". *Journal of Software*, 5(7), 745-752, 2010.